

This Page Is Inserted by IFW Operations  
and is not a part of the Official Record

## BEST AVAILABLE IMAGES

Defective images within this document are accurate representations of the original documents submitted by the applicant.

Defects in the images may include (but are not limited to):

- BLACK BORDERS
- TEXT CUT OFF AT TOP, BOTTOM OR SIDES
- FADED TEXT
- ILLEGIBLE TEXT
- SKEWED/SLANTED IMAGES
- COLORED PHOTOS
- BLACK OR VERY BLACK AND WHITE DARK PHOTOS
- GRAY SCALE DOCUMENTS

**IMAGES ARE BEST AVAILABLE COPY.**

**As rescanning documents *will not* correct images,  
please do not report the images to the  
Image Problem Mailbox.**

(19)



JAPANESE PATENT OFFICE

PATENT ABSTRACTS OF JAPAN

(11) Publication number: 09081185 A

(43) Date of publication of application: 28 . 03 . 97

(51) Int. Cl

G10L 3/00  
G10L 3/00

(21) Application number: 07234043

(22) Date of filing: 12 . 09 . 95

(71) Applicant: ATR ONSEI HONYAKU TSUSHIN  
KENKYUSHO:KK

(72) Inventor: SHIMIZU TORU  
MATSUMAGA SHOICHI  
KOSAKA YOSHINORI

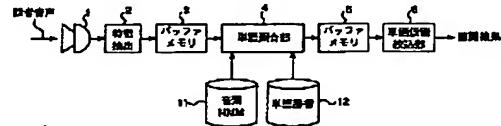
(54) CONTINUOUS VOICE RECOGNITION DEVICE

(57) Abstract:

PROBLEM TO BE SOLVED: To provide a continuous voice recognition device which performs continuous voice recognition of natural uttering with a smaller computing cost than the one using a conventional method.

SOLUTION: A word collating section 4 detects a word-hypothesis of an uttered voice sentence based on the feature parameters of the voice signals of the inputted uttered voice sentence using a one pass viterbi decoding method, for example, computes the likelihood and outputs them. A word narrowing-down section 6 performs word-hypothesis narrowing-down so that the word-hypotheses of the same word outputted from the section 4 through a buffer memory 5 having the same completion time and a different starting time are represented by a single word-hypothesis having a highest likelihood among the entire likelihood computed from the starting time of uttering to the completion time of the work for every leading phoneme environment of the word.

COPYRIGHT: (C)1997,JPO



(19)日本国特許庁 (J P)

(12) 公開特許公報 (A)

(11)特許出願公開番号

特開平9-81185

(43)公開日 平成9年(1997)3月28日

(51)Int.Cl.<sup>6</sup>

G 1 0 L 3/00

識別記号

5 6 1

5 3 5

序内整理番号

F I

G 1 0 L 3/00

技術表示箇所

5 6 1 G

5 3 5

審査請求 有 請求項の数 1 O L (全 6 頁)

(21)出願番号

特願平7-234043

(22)出願日

平成7年(1995)9月12日

(71)出願人 593118597

株式会社エイ・ティ・アール音声翻訳通信  
研究所

京都府相楽郡精華町大字乾谷小字三平谷5  
番地

(72)発明者 清水 徹

京都府相楽郡精華町大字乾谷小字三平谷5  
番地 株式会社エイ・ティ・アール音声翻  
訳通信研究所内

(74)代理人 弁理士 青山 葵 (外2名)

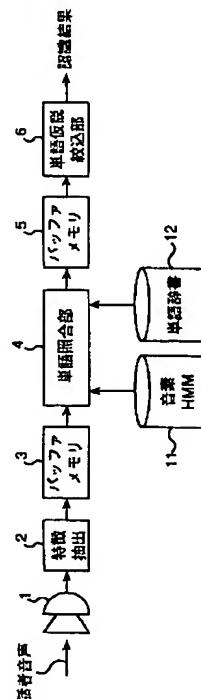
最終頁に続く

(54)【発明の名称】 連続音声認識装置

(57)【要約】

【課題】 従来例に比較してより小さい計算コストで自然発話の連続音声認識を行うことができる連続音声認識装置を提供する。

【解決手段】 単語照合部4は、例えばワンーパス・ビタビ復号化法を用いて、入力される発声音声文の音声信号の特徴パラメータに基づいて上記発声音声文の単語仮説を検出し尤度を計算して出力する。単語絞込部6は、単語照合部4からバッファメモリ5を介して出力される、終了時刻が等しく開始時刻が異なる同一の単語の単語仮説に対して、当該単語の先頭音素環境毎に、発声開始時刻から当該単語の終了時刻に至る計算された総尤度のうちの最も高い尤度を有する1つの単語仮説で代表させるように単語仮説の絞り込みを行う。



m", Proc. of ICASSP95, pp. 73-76, 1995年]において提案されている。

【0004】この第2の従来例の単語グラフの主たるアイデアは、音声認識におけるあいまいさが比較的高い音声信号の領域において単語仮説の候補を処理することである。この利点は、純粹の音声認識は言語モデルのアプリケーションとは切り離されていることと、複雑な言語モデルは、現在認識中の単語に続く公知のステップに適用することができることである。単語仮説の候補の数は音声認識におけるあいまいさのレベルに対応して変化する必要がある。良い単語グラフを効率的に構築するときの困難さは次の通りである。単語の開始時刻は、一般的に、先行する単語に依存している。第1の近似においては、この依存性を直前の先行単語に対して制限を加えることにより、以下に示すようないわゆる単語ペア近似法を得ている。すなわち、単語のペアとその終了時刻が与えられたときに、2つの単語の間の単語境界は別の先行する単語に独立であるということである。この単語ペア近似法は、本来、複数の文又はn個のベスト(最良)である文を効率的に計算するために導入されてきた。この単語グラフは、n個のベストを得るアプローチの方法(以下、nベスト法という。)よりも効率的であると期待されている。この単語グラフを用いた方法では、複数の単語仮説を局所的にのみ発生する必要がある一方、nベスト法においては、各局所的な単語仮説の候補は、n個のベストである文のリストに対して加えるべき全体の文を必要としている。

#### 【0005】

【発明が解決しようとする課題】しかしながら、第1の従来例においては、発声開始からの単語の履歴及び文法状態を管理する必要があるため、間投詞の挿入や、言い淀み、言い直しが頻繁に生じる自然発話の認識に用いた場合、単語仮説の併合又は分割を要する計算コストが極めて大きいという問題点があった。すなわち、音声認識のために必要な処理量が大きくなつて比較的大きな記憶容量を有する記憶装置が必要となる一方、処理量が大きくなるので処理時間が長くなるという問題点があった。

【0006】また、上記第2の従来例の単語ペア近似法においては、先行単語毎に1つの仮説で代表させるが、いまだ近似効果は比較的小さい。このため、上記第1の従来例と同様の問題点が生じる。

【0007】本発明の目的は以上の問題点を解決し、従来例に比較してより小さい計算コストで自然発話の連続音声認識を行うことができる連続音声認識装置を提供することにある。

#### 【0008】

【課題を解決するための手段】本発明に係る連続音声認識装置は、入力される発聲音声文の音声信号に基づいて上記発聲音声文の単語仮説を検出し尤度を計算することにより、連続的に音声認識する音声認識手段を備えた連

#### 【特許請求の範囲】

【請求項1】 入力される発聲音声文の音声信号に基づいて上記発聲音声文の単語仮説を検出し尤度を計算することにより、連続的に音声認識する音声認識手段を備えた連続音声認識装置において、  
上記音声認識手段は、終了時刻が等しく開始時刻が異なる同一の単語の単語仮説に対して、当該単語の先頭音素環境毎に、発声開始時刻から当該単語の終了時刻に至る計算された総尤度のうちの最も高い尤度を有する1つの単語仮説で代表せしめるように単語仮説の絞り込みを行うことを特徴とする連続音声認識装置。

#### 【発明の詳細な説明】

##### 【0001】

【発明の属する技術分野】本発明は、入力される発聲音声文の音声信号に基づいて連続的に音声認識する連続音声認識装置に関する。

##### 【0002】

【従来の技術】従来から、本特許出願人は、自然発話の音声認識を目的として、連続音声認識系(以下、第1の従来例といふ。)の開発を進めている(例えば、従来文献1「Nagai, Takami, Sagayama, "The SSS-LR Continuous Speech Recognition System: Integrating SSS-Derived Allomorphic Models and a Phoneme-Context-Dependent LR Parser", Proc. of ICSLP92, p. 1511-1514, 1992年」及び従来文献2「Shimizu, Monzen, Singer, Matsunaga, "Time-Synchronous Continuous Speech Recognizer Driven by a Context-Free Grammar", Proc. of ICASSP95, pp. 584-587, 1995年」参照)。この第1の従来例では、入力される発聲音声文の音声信号に基づいて、音素隠れマルコフモデル(以下、隠れマルコフモデルをHMMといふ。)と単語辞書を用いて、発声開始からの単語の履歴及び文法状態を管理しながら、音声認識を行っている。

【0003】一方、単語グラフを用いた音声認識方法(以下、第2の従来例といふ。)が、従来文献3「NEY, Aubert, "A Word Graph Algorithm for Large Vocabulary, Continuous Speech Recognition", Proc. of ICSLP94, pp. 1355-1358, 1994年」及び従来文献4「Woodland, Leggetter, Odell, Valtchev, Young, "The 1994 HTK Large Vocabulary Speech Recognition System

続音声認識装置において、上記音声認識手段は、終了時刻が等しく開始時刻が異なる同一の単語の単語仮説に対して、当該単語の先頭音素環境毎に、発声開始時刻から当該単語の終了時刻に至る計算された総尤度のうちの最も高い尤度を有する1つの単語仮説で代表させるように単語仮説の絞り込みを行うことを特徴とする。

## 【0009】

【発明の実施の形態】以下、図面を参照して本発明に係る実施形態について説明する。図1に本発明に係る一実施形態の連続音声認識装置のブロック図を示す。本実施形態の連続音声認識装置は、公知のワンーパス・ビタビ復号化法を用いて、入力される発聲音声文の音声信号の特徴パラメータに基づいて上記発聲音声文の単語仮説を検出し尤度を計算して出力する単語照合部4を備えた連続音声認識装置において、単語照合部4からバッファメモリ5を介して出力される、終了時刻が等しく開始時刻が異なる同一の単語の単語仮説に対して、当該単語の先頭音素環境毎に、発声開始時刻から当該単語の終了時刻に至る計算された総尤度のうちの最も高い尤度を有する1つの単語仮説で代表せるように単語仮説の絞り込みを行う単語仮説絞込部6を備えたことを特徴とする。

【0010】図1において、単語照合部4に接続され、例えばハードディスクメモリに格納される音素HMM11は、各状態を含んで表され、各状態はそれぞれ以下の情報を有する。

- (a) 状態番号
- (b) 受理可能なコンテキストクラス
- (c) 先行状態、及び後続状態のリスト
- (d) 出力確率密度分布のパラメータ
- (e) 自己遷移確率及び後続状態への遷移確率

なお、本実施例において用いる音素HMMは、各分布がどの話者に由来するかを特定する必要があるため、所定の話者混合HMMを変換して作成する。ここで、出力確率密度関数は34次元の対角共分散行列をもつ混合ガウス分布である。

【0011】また、単語照合部4に接続され、例えばハードディスクに格納される単語辞書12は、音素HMM11の各単語毎にシンボルで表した読みを示すシンボル列を格納する。

【0012】図1において、話者の発聲音声はマイクロホン1に入力されて音声信号に変換された後、特徴抽出部2に入力される。特徴抽出部2は、入力された音声信号をA/D変換した後、例えばLPC分析を実行し、対数パワー、16次ケプストラム係数、△対数パワー及び16次△ケプストラム係数を含む34次元の特徴パラメータを抽出する。抽出された特徴パラメータの時系列はバッファメモリ3を介して単語照合部4に入力される。

【0013】単語照合部4は、ワンーパス・ビタビ復号化法を用いて、バッファメモリ3を介して入力される特徴パラメータのデータに基づいて、音素HMM11と単

語辞書12とを用いて単語仮説を検出し尤度を計算して出力する。ここで、単語照合部4は、各時刻の各HMMの状態毎に、単語内の尤度と発声開始からの尤度を計算する。尤度は、単語の識別番号、単語の開始時刻、先行単語の違い毎に個別にもつ。また、計算処理量の削減のために、音素HMM11及び単語辞書12とに基づいて計算される総尤度のうちの低い尤度のグリッド仮説を削減する。単語照合部4は、その結果の単語仮説と尤度の情報を発声開始時刻からの時間情報（具体的には、例えればフレーム番号）とともにバッファメモリ5を介して単語仮説絞込部6に出力する。

【0014】単語仮説絞込部6は、単語照合部4からバッファメモリ5を介して出力される単語仮説に基づいて、終了時刻が等しく開始時刻が異なる同一の単語の単語仮説に対して、当該単語の先頭音素環境毎に、発声開始時刻から当該単語の終了時刻に至る計算された総尤度のうちの最も高い尤度を有する1つの単語仮説で代表せらるるように単語仮説の絞り込みを行った後、絞り込み後のすべての単語仮説の単語列のうち、最大の総尤度を有する仮説の単語列を認識結果として出力する。本実施形態においては、好ましくは、処理すべき当該単語の先頭音素環境とは、当該単語より先行する単語仮説の最終音素と、当該単語の単語仮説の最初の2つの音素とを含む3つの音素並びをいう。

【0015】例えば、図2に示すように、(i-1)番目の単語 $W_{i-1}$ の次に、音素列 $a_1, a_2, \dots, a_n$ からなるi番目の単語 $W_i$ がくるときに、単語 $W_{i-1}$ の単語仮説として6つの仮説 $W_a, W_b, W_c, W_d, W_e, W_f$ が存在している。ここで、前者3つの単語仮説 $W_a, W_b, W_c$ の最終音素は/ $x$ /であるとし、後者3つの単語仮説 $W_d, W_e, W_f$ の最終音素は/ $y$ /であるとする。終了時刻 $t_e$ と先頭音素環境が等しい仮説（図2では先頭音素環境が“ $x/a_1/a_2$ ”である上から3つの単語仮説）のうち総尤度が最も高い仮説（例えば、図2において1番上の仮説）以外を削除する。なお、上から4番めの仮説は先頭音素環境が違うため、すなわち、先行する単語仮説の最終音素が $x$ ではなく $y$ であるので、上から4番めの仮説を削除しない。すなわち、先行する単語仮説の最終音素毎に1つのみ仮説を残す。図2の例では、最終音素/ $x$ /に対して1つの仮説を残し、最終音素/ $y$ /に対して1つの仮説を残す。

【0016】以上の実施形態においては、当該単語の先頭音素環境とは、当該単語より先行する単語仮説の最終音素と、当該単語の単語仮説の最初の2つの音素とを含む3つの音素並びとして定義されているが、本発明はこれに限らず、先行する単語仮説の最終音素と、最終音素と連続する先行する単語仮説の少なくとも1つの音素とを含む先行単語仮説の音素列と、当該単語の単語仮説の最初の音素を含む音素列とを含む音素並びとしてもよい。

## 【0017】

【実施例】本発明者は、図1の連続音声認識装置の有効性を確認するために、自然発話データベースを用いて単語グラフ生成実験を行なった。“トラベル・プランニング”をタスクとした本出願人が所有する音声言語データベース（例えば、従来文献5「Morimoto et al., “A Speech and Language Database for Speech Translation Research”, Proc. of ICSLP 94, pp. 1791-1794, 1994年」参照。）の「ホテル予約」に関する対話（申込者側5話者の発声：5対話、56発声、687語）を用いて評価した。音響分析は、標本化周波数12kHz、フレーム間隔5ms、ハミング窓20msの仕様で分析し、特徴パラメータとして、1～16次LPCケプストラム、1～16次ΔLPCケプストラム、対数パワー、Δ対数パワーを用いた。音響モデル（隠れマルコフ網：401状態、5混合）は、朗読音声（150文）を用いて学習した音響モデルをさらに上記データベースのテストデータに現れない話者9名の発声（128発声）を用いて発話様式に適応した。また、言語モデルは、「ホテル予約」を含む“トラベル・プランニング”全般（18、315発声、229、159語）を用いて学習した。単語バープレキシティは、55.9であった。単語辞書（1,113語）は、評価データの語彙を全て含んでおり、予め登録されていない未知語（未登録語ともいう。）はないものとした。

【0018】次いで、開始時刻の異なる単語仮説の絞り込み効果について以下に説明する。図3に、絞り込みを行なった場合（本実施形態）と絞り込みを行なわない場合の各単語仮説の先行単語数の分布の比較を示す。絞り込みを行なうことによって、平均先行単語数が3.59から1.70に削減された。また、絞り込みを行なわなかった場合に対して、開始時刻の違いを無視した平均先行単語数を計算したところ、1.36であった。この結果から、単語の先頭音素環境ごとに1つの仮説で代表させる本発明の方法は、少ない計算量で、先行単語毎に1つの仮説で代表させる第2の従来例の単語ペア近似法にかなり近い効果が得られると考えられる。

【0019】以上説明したように、本実施形態によれば、終了時刻が等しく開始時刻が異なる同一の単語の単語仮説に対して、当該単語の先頭音素環境毎に、发声開始時刻から当該単語の終了時刻に至る計算された総尤度のうちの最も高い尤度を有する1つの単語仮説で代表さるよう単語仮説の絞り込みを行う。すなわち、先行単語毎に1つの単語仮説で代表させる第2の従来例の単語ペア近似法に比較して、単語の先頭音素の先行音素（つまり、先行単語の最終音素）が等しいものをひとまとめに扱うために、単語仮説数を削減することができ、近似効果は大きい。特に、語彙数が増加した場合において削減効果が大きい。従って、当該連続音声認識装置を、間投詞の挿入や、言い淀み、言い直しが頻繁に生じる自然発話の認識に用いた場合であっても、単語仮説の併合又は分割に要する計算コストは従来例に比較して小さくなる。すなわち、音声認識のために必要な処理量が小さくなり、それ故、単語照合部4のワーキングメモリ（図示せず。）、バッファメモリ5及び単語仮説絞込部6のワーキングメモリ（図示せず。）などの音声認識のための記憶装置において必要な記憶容量は小さくなる一方、処理量が小さくなるので音声認識のための処理時間を短縮することができる。

## 【0020】

10

20

30

40

50

【発明の効果】以上詳述したように本発明によれば、入力される発聲音声文の音声信号に基づいて上記発聲音声文の単語仮説を検出し尤度を計算することにより、連続的に音声認識する音声認識手段を備えた連続音声認識装置において、上記音声認識手段は、終了時刻が等しく開始時刻が異なる同一の単語の単語仮説に対して、当該単語の先頭音素環境毎に、发声開始時刻から当該単語の終了時刻に至る計算された総尤度のうちの最も高い尤度を有する1つの単語仮説で代表させるように絞り込みを行う。すなわち、先行単語毎に1つの単語仮説で代表させる第2の従来例の単語ペア近似法に比較して、単語の先頭音素の先行音素（つまり、先行単語の最終音素）が等しいものをひとまとめに扱うために、単語仮説数を削減することができ、近似効果は大きい。特に、語彙数が増加した場合において削減効果が大きい。従って、当該連続音声認識装置を、間投詞の挿入や、言い淀み、言い直しが頻繁に生じる自然発話の認識に用いた場合であっても、単語仮説の併合又は分割に要する計算コストは従来例に比較して小さくなる。すなわち、音声認識のために必要な処理量が小さくなり、それ故、音声認識のための記憶装置において必要な記憶容量は小さくなる一方、処理量が小さくなるので音声認識のための処理時間を短縮することができる。

## 【図面の簡単な説明】

【図1】 本発明に係る一実施形態である連続音声認識装置のブロック図である。

【図2】 図1の連続音声認識装置における単語仮説絞込部6の処理を示すタイミングチャートである。

【図3】 図1の連続音声認識装置の実験結果における、単語間の遷移における単語仮説の絞り込み効果を示す先行単語の個数に対するノード数のグラフである。

## 【符号の説明】

1…マイクロホン、

2…特徴抽出部、

3, 5…バッファメモリ、

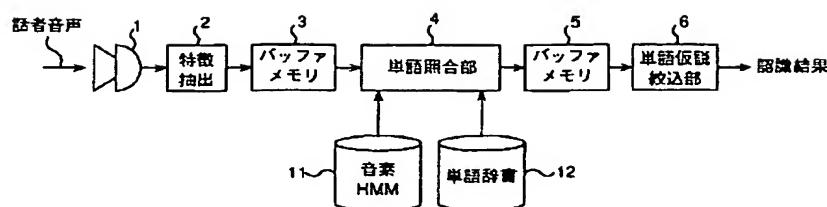
4…単語照合部、

6…単語仮説絞込部、

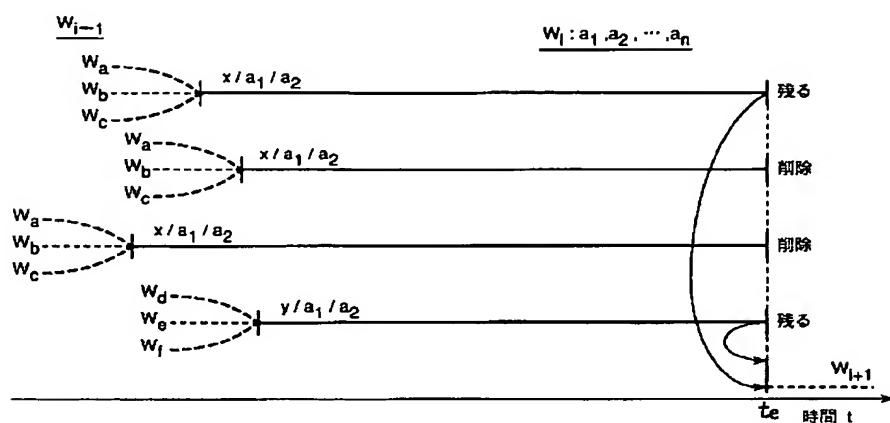
11…音素HMM、

1 2 … 単語辞書。

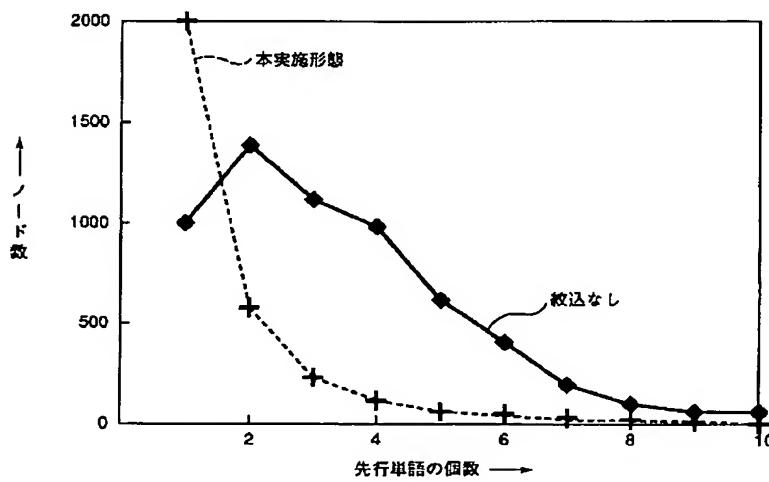
【図 1】



【図 2】



【図 3】



フロントページの続き

(72) 発明者 松永 昭一

京都府相楽郡精華町大字乾谷小字三平谷5  
番地 株式会社エイ・ティ・アール音声翻  
訳通信研究所内

(72) 発明者 匂坂 芳典

京都府相楽郡精華町大字乾谷小字三平谷5  
番地 株式会社エイ・ティ・アール音声翻  
訳通信研究所内